移动数字图书馆资源的情境感知个性化推荐方法研究*

洪　亮　钱　晨　樊　星
(武汉大学信息管理学院　武汉　430072)

摘要: 【目的】结合移动数字图书馆的资源布局及推送特征, 为其设计一种基于情境感知的个性化资源推荐方式。【方法】基于相似用户有相似选择的考虑, 引入角色的概念模拟用户兴趣选择, 设计一种有效的 WSSQ 算法构建用户信任网络, 由此给出改进的情境感知推荐方法, 并在扩展的 Epinion 数据集上进行仿真实验。【结果】通过实验证明了本方法是可行的, 且在 MAE、RMSE 等指标下均优于其他推荐方法, 体现出良好的推荐精度。【局限】在用户样本足够大时会面临情境和角色稀疏的问题。【结论】本研究为移动数字图书馆资源推荐提供了一种思路, 有利于其推荐系统的改进和完善。

关键词: 移动数字图书馆　情境感知推荐　WSSQ 算法
分类号: G250

1　引　言

社会信息化和数字化程度的不断加深, 产生了爆炸式的信息环境, 而移动终端的普及, 则使用户每时每刻都会受到无数碎片化、无序化信息的冲击。数据量急速扩张与用户获取数据的有限性之间的矛盾, 使得用户主动的检索查询效率降低, 是当前信息过载问题的集中体现。为了适应信息过载的大环境和更好地服务用户, 作为社会信息中枢的图书馆也开始向移动数字图书馆发展。移动数字图书馆是图书馆在移动互联环境下的新发展, 主要实现图书馆各类资源在手持设备上的同一检索功能, 以及满足用户可以随时随地获取和阅读文献正文的需要。学界普遍认同移动数字图书馆重在对传统服务模式的创新发展、而非简单执行信息服务的网络化的观点[1], 如何实现创新, 则重在考察实际环境和需求。移动数字图书馆依托实体馆丰富的、有序的馆藏资源, 资源质量较高, 盛小平[2]将资源可用性、权威性作为移动数字图书馆资源评价的要素, 用户利用率则是这些评价方式最朴素且实际的体现。用户能否获得准确获取资源的途径、是否得到了阅读意愿的满足和优越的使用体验, 都是移动数字图书馆服务评价的重要指标。在手持移动终端成为主要信息接收源的环境中, 图书馆用户将时刻受到丰富且不断变化的情境信息的影响而有不同的资源需求, 或者说阅读偏好, 从而如何动态满足用户变化着的需求是移动数字图书馆在当前形势下的重大挑战。

针对以上问题, 个性化推荐系统的使用将是一种有效的解决方案。推荐系统输入用户信息, 利用推荐算法给出合理的推荐结果。推荐系统省去了用户自搜索的过程, 个性化的推荐侧重于搜集用户兴趣, 有针对性地进行推荐, 可以更好地满足用户需求。如果考虑用户兴趣在情境因素影响下的变化, 即情境感知的推荐, 则为解决移动数字图书馆用户需求变化的问题给出了一个解答。

通讯作者: 洪亮, ORCID: 0000-0002-1466-9843, E-mail: hong@whu.edu.cn。

*本文系国家自然科学基金青年基金项目“移动社会网络中基于信任关系的情境感知推荐研究”(项目编号: 61303025)和湖北省高校省级教学改革研究项目“‘慕课’背景下信息素质教育课程的变革研究”(项目编号: 2015009)的研究成果之一。

2　相关研究进展

关于情境感知推荐、用户信任网络的研究一直是推荐系统研究的重要内容，受到众多学者的重视，也有了很多成果。

Forestier等[3]的调查结果显示用户角色是广泛存在于社会网络中，并随着情境的变化而不断变迁的。Adomavicius等[4]讨论了如何在推荐系统中模拟情境的问题，而Anand等[5]提出了将用户情境信息结合进入推荐方法的新方式。Bao等[6]提出了一种无监督方法用以模拟移动用户的个性化情境信息。Sen等[7]的推荐系统考虑进了情境信息来进行情境感知的推荐。Karatzoglou等[8]提出一种多元推荐方法(MV)将情境感知与协同过滤推荐结合起来，Rendle等[9]则提出运用分解机(FM)模拟情境信息，从而在MV方法的基础上提高了推荐精度、降低了算法复杂度。但是已有的这些方法都没有考虑用户群组所共有的情境感知的兴趣和选择倾向，以及他们之间的信任关系。

基于信任关系的推荐往往假设一个存在于用户之间的信任网络。Massa等[10]研究了信任网络中的信任传播问题，并提出一种信任感知的推荐方式。Jamali等[11]提出一种随机游走模型——TrustWalker，用以结合基于信任关系的方法和协同过滤方法来进行推荐。他们也给出了一个创新的Top-N Item推荐方式[12]，该方法使用来自基于信任和协同过滤两种方法的结果的加权结合。Dubois等[13]采用信任路径将用户进行聚类，形成信任群体，从而提高推荐精度。Ma等[14]提出一种综合用户个人喜好和其信任朋友偏好的推荐框架。

综上，目前情境感知推荐的研究中，主要存在用户兴趣模型脱离实际、忽略用户信任关系这两类问题。具体而言，现存的情境感知推荐系统都是基于当下情境，来考察用户在这一情境下的共同兴趣，但实际上用户总是在一些彼此联系的情境中都拥有相同的信息偏好；典型的情境感知推荐系统总是假定用户决策的独立性，而忽略了用户间的关系和交互，但Massa等[10]的研究已经证明用户的决策明显受到其信任对象的影响。基于此，本文引入角色的观念来表示多个情境下用户的共同兴趣，并基于角色来寻找相似用户，构建信任模型。另一方面，基于信任推荐的研究也存在着主观上认为用户间信任度不随情境变迁而变化、社会信任网络中用户信任关系都被显性地表达出来等不符合实际情况的设定。但目前已有的这些方法都没有考虑信任关系在不同情境下的表现，这会降低推荐质量。因此，本文利用信任模型进行用户间隐性信任关系的计算来充实信任网络，并将情境作为参数纳入用户信任值、相似度的计算中，以体现情境变化对用户信任关系产生的影响。

3　推荐方案概述

本文提出的推荐方案包括线上和线下两个部分，如图 1 所示，具体包括三个步骤。

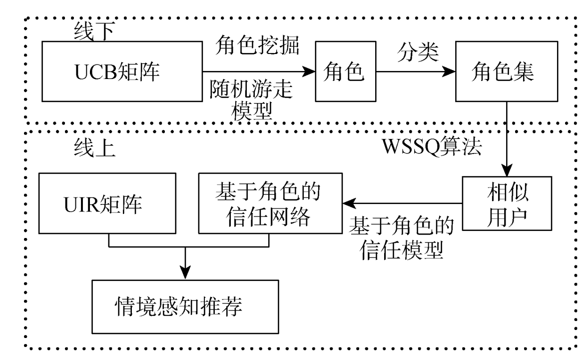


图 1　推荐步骤

(1) 利用角色挖掘算法从 UCB 矩阵中找出角色，并利用随机游走模型测度每个角色与不同情境的关联度。这个工作将在线下完成。UCB 矩阵即“用户–情境–行为”矩阵，该矩阵行为用户、列为情境，每个元素表示用户在相应情境下的选择行为。本文以用户对项目的喜好和选择作为用户行为的体现，这些项目被描述成诸如“经济评论”、“经济学”等内容标签，而这些内容标签来自移动数字图书馆采取的资源分类标签，推荐的结果则为标注相应分类标签的移动数字图书馆馆藏资源。本文中情境则被定义为一种时空情形的集合，包括地点、时间等会影响用户行为的因素。

(2) 构建基于角色的信任模型，计算用户间的相似度。将使用一种有效的 WSSQ 算法来找出用户 u 的所有相似用户。这个过程将在线上完成。

(3) 基于针对每个用户建立的角色信任模型，预测用户对不同项目的评价，并将评价高的项目推荐给用户。这个过程也将在线上完成。Golbeck[15]、McPherson 等[16]的研究证明社会网络中同一性是普遍存在的，并能够提升用户之间的相互信任，即用户相

似度越高，他们之间的信任关系就越紧密。本文通过计算隐性信任度来构建一个基于角色的信任网络。这个信任网络是情境感知的、是个性化的，用户的信任值和信任对象都将跟随情境变迁而改变。然后，基于情境 c 下的这样的信任网络和 UIR 矩阵，通过以下两个步骤完成推荐：决定各个项目即用户行为选择；通过在基于角色的信任网络中的用户对于项目 v 的评级来预测该项目的未知评级，将项目按评级结果倒序排列并为用户推荐前 k 个项目。UIR 矩阵即"用户–项目–评级"记录用户对于每个项目的评价，这个评价将体现该用户对该项目的偏好。

4 推荐模型构建

4.1 角色挖掘

在角色挖掘方法中，角色被定义为特定情境下某一用户群体的共有行为集合。因此利用角色来代表用户的共同兴趣是可行的，基于角色讨论用户相似度也能够贴合实际。例如在图 2 中，用户 1、2、5 在地铁和自习室这两种情境下做出相同的选择，而用户 2、3、4 在寝室/家和 CD 店这两种情境下共享同样的行为倾向，因此可以理解为用户 1、2、5 在"地铁"、"自习室"情境下演绎角色 r_1，用户 2、3、4 在"寝室/家"、"CD 店"情境下演绎角色 r_2。更确切地，引入定义 tile 表示 UCB 矩阵中任意的同列元素相同的子矩阵，从而将角色定义为至少包含 m_t 行、n_t 列的 tile。用户的决定通常会受到其所属角色的影响，例如用户 2、3、4 在寝室/家和 CD 店中的选择都与流行音乐相关，r_2 可被视为流行音乐爱好者，因此用户 2、3、4 在寝室/家和 CD 店中时可能会对流行音乐相关的内容感兴趣。本文提出的推荐方法将关注在至少 n_t 种情境中，由至少 m_t 个用户共有的行为，而 n_t 和 m_t 值的选取则是取决于具体应用。

在现有的基于角色的访问控制(RBAC)[17]中，已有为布尔值矩阵设计的角色挖掘算法，但这种算法并不能直接运用于本文中非布尔值的角色矩阵。事实上，UCB 矩阵中的角色挖掘问题可以等同于 Minimal Tiling 问题[17]，这个问题已被证明是 NP 复杂的。Minimal Tiling 问题旨在寻求包含 UCB 矩阵中所有非空元素的 tile 内含的最少元素值。本文提出一种运用

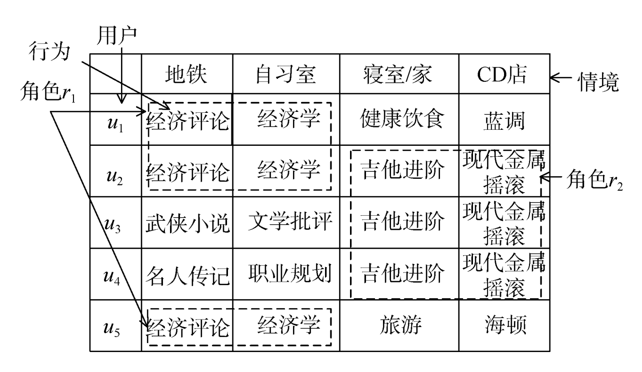


图 2 角色示例

Conditional Database 的学习启发式的角色挖掘算法。这种算法将初始角色集 ROLES 设置为空集，然后为 UCB 矩阵的每一列 c_i 构建 c_i-conditional database。对于每一个 c_i，考虑所有的满足 $1\leqslant i<j\leqslant$ 的 c_j，在每一对(c_i, c_j)中找出所有至少 m_t 行的 tile(用 t 表示)。对找出的 t，检验是否存在 t'∈ROLES，使得 t 与 t'可以合并(两个 tile 可以合并当且仅当两者拥有相同的行)。若存在，则合并 t 和 t'；否则直接将 t 并入 ROLES。最终得到至少拥有 n_t 列的 tile 组成的集合 ROLES。例如图 3 中的 UCB 矩阵，该矩阵从图 2 中提取出来，第一列代表 5 位用户，第一行代表 4 种情境，m_t 至 n_t 分别代表"经济评论"、"经济学"、"吉他进阶"、"现代金属摇滚"。假设 m_t 与 n_t 都为 2，构建 c_i-conditional database，如 $c_1\text{-cdb}=\{(c_1\cap c_2),\cdots,(c_1\cap c_4)\}$，剔除所有列数少于 2 的 tile，得到满足要求的 ROLES。基于 ROLES，将 UCB 矩阵分为角色–情境–行为(RCB)矩阵和用户–角色(UR)矩阵。RCB 矩阵行代表角色、列代表情境，每一元素为对应情境下对应角色的行为。UR 矩阵中行代表用户、列代表角色，每一元素代表对应用户是否演绎对应角色，其值为布尔型。

	c_1	c_2	c_3	c_4
u_1	b_1	b_2		
u_2	b_1	b_2	b_3	b_4
u_3			b_3	b_4
u_4			b_3	b_4
u_5	b_1	b_2		

图 3 UCB 矩阵

进行角色挖掘之后，每一用户可用其角色集 $R(u,c)=\{r_1,\cdots,r_k\}$ 表示，c 为当前情境，r_1 到 r_k 表示在 c 下用户 u 演绎的角色。在 RCB 矩阵中，每个角色都会对应不同的情境感知行为，因此相应地，如果新用户 u'在 RCB 矩阵中对应于角色 r 有相同的情境感知行为，则 u'演绎角色 r；且如果 u'行为随时间变化，其角色集会被及时更新。此外，现实中还可能存在不参与演绎任何角色的用户，这些用户在特定情境中的兴趣及倾向并不与任何用户群体一致，但他们仍拥有一系列不同情境下的行为集合，对于这样的用户，可以基于特定情境下的共有行为找出该用户的相似用户群，从而用行为集的相似度来衡量该用户与其他用户之间的相似度。角色挖掘之后将进行相应情境下角色权重的计算，即测量角色 r 与情境 c 间的关联强度，使用随机游走模型[18]进行角色权重的测度，并标记为 W(r, c)。显然，如果用户 u 在情境 c 下参与演绎角色 r，那么 W(r, c) 应该比该用户其他角色的权重值更大。

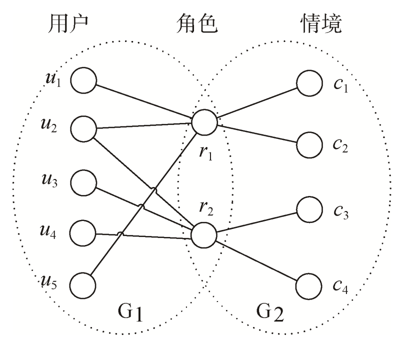


图 4　随机游走模型

如图 4 所示，在用户集和角色集间构造二部图 G_1，连接用户和角色当且仅当该用户的角色集包含该角色；在角色集和情境集间构造二部图 G_2，连接角色和情境当且仅当在 UCB 矩阵中该角色覆盖了该情境。G_1 和 G_2 组合在一起构成图 G，W(r, c)将由重启式随机游走模型[18]测度出来，即粒子从节点 r 出发最终停留在节点 c 的稳态概率。

4.2　基于角色的信任模型

现实情况下用户之间的信任关系有显性和隐性两种体现方式，但显性信任多体现为交流、评论等，这些数据比较稀薄，无法准确度量用户信任度，因而构建用户信任模型，解决用户 u 与用户 u'间的隐形信任值的计算问题，这个值不是布尔型的，标记为 T(u, u', c)。用户相似度和用户的交流互动是模型建构的关键。

本文基于用户的角色集给出情境感知的用户相似度测量方式。文献[19]提出 Jaccard 相似度公式，将两要素 s 与 r 之间的相似度定义为 s 与 r 交集和并集的 L_1-范数的比值。本文在 Jaccard 相似度公式的基础上进行改进，以模拟出用户相似度。设在情境 c 下，有用户 u 和 u'，他们对应的角色集分别为 R(u, c)、R(u', c)，则用户相似度可表示为:

$$S(u,u',c)=\frac{\|R(u,c)\cap R(u',c)\|}{\|R(u,c)\cup R(u',c)\|}=\frac{\sum_{r\in R(u,c)\cap R(u',c)}W(r,c)}{\sum_{r\in R(u,c)\cup R(u',c)}W(r,c)} \quad (1)$$

$\|R(u,c)\cap R(u',c)\|$，$\|R(u,c)\cup R(u',c)\|$ 分别表示 $R(u,c)\cap R(u',c)$ 和 $R(u,c)\cup R(u',c)$ 的 L_1-范数。

接下来考虑用户互动。Liu 等[20]认为社会网络中的用户互动例如聊天、评论等影响了用户的相互信任，一个用户往往更愿意去信任曾与其有过交流的另一用户提供的信息。在本文的模型中，使用 $I_{uu'}$代表用户 u 与 u'间的互动次数，将用户 u、u'间的信任值用 u'成为 u 的信任对象的条件概率来模拟，从而提出下列公式将信任度表示为:

$$T(u,u',c)=P(F(u,u',c)=1\,|\,S(u,u',c),I_{uu'},I_{u'u}) \quad (2)$$

F(u,u',c)=1 意为在情境 c 下用户 u'是 u 的信任对象。

由于 Logistic 回归模型具有适用连续和离散类型的变量、在大型数据集中效率更高等优点，本文选取该模型以模拟信任关系。按 Logistic 回归模型展开公式(2)，以考察 S(u, u', c)、$I_{uu'}$、$I_{u'u}$ 对 T(u, u', c)的影响。

$$\begin{aligned}T(u,u',c)&=P(F(u,u',c)=1\,|\,S(u,u',c),I_{uu'},I_{u'u})\\&=\frac{1}{1+e^{-(\beta_1\cdot S(u,u',c)+\beta_2\cdot I_{uu'}+\beta_3\cdot I_{u'u}+\beta_0)}}\end{aligned} \quad (3)$$

β_0、β_1、β_2、β_3 是被训练的参数，本文采用显性信任关系作为训练数据以得出参数值。首先根据二项分布的理念提出如下期望函数:

$$L=\prod_{u,u'\in D}P(u,u',c)^{F(u,u',c)}(1-P(u,u',c))^{1-F(u,u',c)} \quad (4)$$

P(u, u', c) 表示 F(u,u',c)=1 的概率。对公式(4)两端取对数，则可得到对数期望函数:

$$\begin{aligned}\ln L&=\sum_{u,u'\in D}[F(u,u',c)\ln P(u,u',c)+(1-F(u,u',c))\ln(1-P(u,u',c)]\\&=\sum_{u,u'\in D}[(F(u,u',c)-1)(\beta_1\cdot S(u,u',c))+\beta_2\cdot I_{uu'}+\beta_3\cdot I_{u'u}+\beta_0)\\&\quad-\ln(1+e^{-(\beta_1\cdot S(u,u',c)+\beta_2\cdot I_{uu'}+\beta_3\cdot I_{u'u}+\beta_0)})]\end{aligned} \quad (5)$$

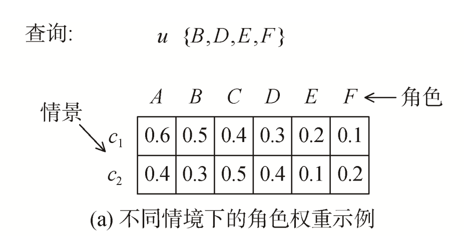
接下来采用基于梯度的算法估算β_0、β_1、β_2、β_3，从而使 L 最大化。令 lnL 导数中的参数为 0，然后运用牛顿–拉夫森(Newton-Raphson)迭代方法对参数进行估值。

4.3 发现相似用户

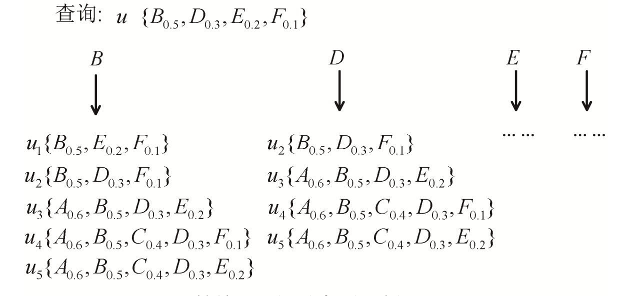
从公式(3)中可以看出用户相似度是信任模型中的关键因素，通过找出情境 c 下用户 u 的相似用户 u'并计算相似度 S(u, u', c)，即可得到信任值 T(u, u', c)。在线上推荐的过程中，首先要解决找出相似用户的问题，具体而言，就是在已知情境 c、用户 u 和相似度阈值δ的情况下，找出用户 u 的相似用户 u'，使得 u 与 u'之间的相似度 S(u, u', c)≥δ。本文采用 WSSQ (Weighted Set Similarity Query)算法来解决这个问题。

(1) WSSQ 算法

WSSQ 算法输入有序角色集和相似度阈值δ，输出满足相似度大于阈值这一条件的所有相似用户其对应相似度计算值。角色集中的角色按情境感知的权重逆序排列，而相似度阈值δ则由数据集训练得出，其最佳值为 0.6，实验证明默认输入该值时可以使信任度测量精度达到峰值 89.1%。算法分为线下和线上两各部分完成，示例如图 5 所示：



(a) 不同情境下的角色权重示例



(b) 情境c_1下的逆序列示例

图 5 WSSQ 算法示例

在线下部分，首先为用户 u 的所有角色按照角色权重建立逆序索引，如图 5(b)中 Query 所示。如前文所述，角色代表着用户的兴趣倾向，是随情境变迁而不断变化的，因而角色的权重值也是依赖于情境的，如图 5(a)所示，在 c_1、c_2 两种情境下，各个角色均有不同的权重值，所以有多少种情境，就对应多少种角色逆序列。当系统生成 k 个情境 c_i(i=1,⋯, k)时，对每一个情境，每一个角色下都保留 k 个逆序用户列 $L_i(r)$，且在 $L_i(r)$中的每一个用户 u 都对应各自的角色集 R(u, c_i)，从而用户与角色集在分析中可替换表达。在 $L_i(r)$中，将所有角色集 R(u, c_i)中的角色按照情境 c_i 下的权重进行倒序排列，再将每个逆序列 $L_1(r)$中的角色集按其 L_1-范数进行升序排列。如图 5(b)所示，角色 B 在情境 c_1 下经系统生成逆序列 $L_1(r)$，其中有 5 个用户演绎了角色 B，用户 1 的所有角色是 B、E、F，根据情境 c_1 下的权重值将这三个角色进行逆序呈现。

在线上部分，当给出情境 c 和用户 u 后，运用 Prefix 过滤和 L_1-范数修剪两种过滤技术来找出所有的相似用户 u'。在 Prefix 过滤过程中，找出满足条件的逆序列；在 L_1-范数修剪过程中，对找出的逆序列剔除一些不必要的角色集来节省搜索空间。通过这样的步骤，对用户 u 的每一个相似用户 u'都可以计算出相似度 S(u, u', c)。

(2) Prefix 过滤

设有情境 c 和该情境下的用户 u，将 u 的所有角色按照权重倒序排列，形成有序角色集(Ranked Role Set)，简记为 **R**(u, c)。p-prefix 即为 **R**(u, c)中的前 p 个角色，记为 **R**(u, c, p)。当有用户 u 和用户 u'，如果 u'不拥有 **R**(u, c, p)里的任何角色，本文提出如下公式将 S(u, u', c)的 Upper Bound 表示为：

$$\text{UB-P}(u,u',c)=1-\frac{\sum_{r\in \mathbf{R}(u,c,p)} W(r,c)}{\sum_{r\in \mathbf{R}(u,c)} W(r,c)} \tag{6}$$

Prefix 过滤运用的原理是：设有情境 c 和用户 u，对另一个用户 u'，如果 **R**(u', c)在 p-prefix 上对 **R**(u, c)没有覆盖，则 S(u, u', c)的 Upper Bound 可通过公式(6)计算出，基于此可以找出 **R**(u, c)的最大 p-prefix。最大 p-prefix 意味着：如果用户 u'的角色覆盖 **R**(u, c, p–1)，那么 UB-P(u, u', c)≥δ；如果没有覆盖，则 UB-P(u, u', c)<δ。同样，对于 **R**(u, c, p)中的任何角色，如果 u'的角色集不被包括在任何 L(r)内，那么 UB-P(u, u', c)一定小于δ。因此，为了找到所有的相似角色集，只需要所有满足了 $r\in\mathbf{R}(u,c,p)$ 的逆序列 L(r)。

(3) L_1-范数修剪

给出情境 c 下的用户 u，根据 Prefix 过滤可以找出

其最大 p-prefix$\{r_1,\cdots,r_p\}$。然后将逐一输入逆序列 $L(r_i)$。由于一个用户可能出现在不同的逆序列中，笔者采取下列措施：如果一用户在 $L(r_i)$中的角色集 R(u, c)有一个角色 r_j，满足 $1\leqslant j\leqslant i-1$，那么 R(u, c)将不被输入，因为在访问 $L(r_j)$时就已输入过。此外，访问 $L(r_i)$时，一些角色集可以运用相似度的 Upper Bound 方法进行剔除。

当有有序角色集 $\mathbf{R}(u,c)=\{r_1,\cdots,r_n\}$ 和 $L(r_i)$中的一个用户的角色集 $R(u',c)$，满足 $1\leqslant i\leqslant p$，如果满足除了 r_i 属于 $R(u',c)$ 以外其他角色(r_1 至 r_{i-1})都不属于 $R(u',c)$，本文提出如下公式将 $S(u,u',c)$ 的 L_1-范数 Upper Bound 定义为：

$$\text{UB-L}(u,u',c)=\frac{\sum_{i}^{n}W(r_j,c)}{\sum_{r'\in R(u',c)}W(r',c)}=\frac{\sum_{i}^{n}W(r_j,c)}{\|R(u',c)\|_1} \quad (7)$$

4.4 Top k 推荐

首先找出情境 c 下 u 演绎的所有角色。对每一个 R(u,c)中的角色 r，检查其在 UCB 矩阵里是否对应着情境 c，如果是，则 r 是 u 在 c 下演绎的角色。如前文所述，角色是一些基于情境的行为的集合，这些行为即用户所倾向于选择的内容，当 u 演绎某一角色，则 u 在情境 c 下可能会对相应的内容感兴趣。对每一种选择倾向，推荐系统会预测用户 u 给出的评级。用户往往会参照其信任对象的选择，因而系统会找出 u 的所有信任对象，并计算 u 在情境 c 下对选项 v 的评价，用 RT(u,v,c)表示，本文提出如下公式表示该值：

$$RT(u,v,c)=\frac{\sum_{u'\in U(u,c)}UIR[u'][v]T(u,u',c)}{\sum_{u'\in U(u,c)}T(u,u',c)} \quad (8)$$

UIR[u'][v] 表示用户 u'会给予选项 v 的评级，U(u,c)表示在情境 c 下已对选项 v 进行了评定的用户 u 的信任用户的集合。最终评价最高的前 k 个选项将在情境 c 下被推荐给用户 u。

此外，还存在三类特殊用户。第一种是只表现出极少的行为的，第二种是有与其他用户都不同的独特行为的，这两种用户都几乎不演绎任何角色。对于这些用户，将基于共有的情境感知的行为找出其相似用户。第三种是在当下情境中没有任何行为，但在其他情境中演绎了众多角色的，对于这些用户，基于角色集的相似度找出其相似用户。基于用户相似度，可以构建每一个特殊用户在当下情境中的信任网络，并同样推荐预测评价最高的前 k 个选项。

4.5 推荐系统实验及质量评价

(1) 实验数据描述

实验数据来源于扩展的 Epinions 数据集①。Epinions 是一个允许用户从数值 1 到 5 对项目进行评分的用户点评网站，用户在网站上表达了显性信任关系。本文的实验主要运用该网站上的图书评价数据，用户在移动终端对图书的阅读与评价形成了一个移动数字图书馆。扩展的 Epinions 数据库包括 132 000 位用户，他们共提供了 717 667 条信任表达、对 1 560 144 篇文章给出了共计 13 668 319 条评分记录。由于原始数据集并不依赖于情境，笔者运用情境修正方法[8]向原始数据添加两个人工情境因素，即选择 90%的项目，并随机抽取 50%的评分进行修正，使得情境对修正数据集中的评分项产生影响。

(2) 方法比较分析

在实验结果分析中，针对基于角色的信任网络推荐方法(RRTN)和下述方法进行比较：

①$RRTN_t$ 方法：$RRTN_t$ 方法是 RRTN 的情境独立版本，只基于用户 u 和 u'的共同行为来计算相似度，即运用 $T(u,u')$ 而不是 $T(u,u',c)$ 进行推荐。

②$RRTN_c$ 方法：$RRTN_c$ 方法并不为所有用户构建基于角色的信任网络，而是基于用户 u 在情境 c 下所演绎的角色为其做推荐。与 $RRTN_c$ 方法进行比较以评估 RRTN 方法的情境感知模块。

③RSTE 方法：RSTE 方法[14]即基于社会信任的推荐，其核心思想在于每位用户的选择都体现了其个人偏好和信任用户的举荐。

④MV 方法：MV 方法[8]被设计用于情境感知推荐，它运用一种基于张量分解的协同过滤方法，该方法将数据模拟为包含用户–项目–情境的 N 维张量而不是传统的用户–项目的二元状态。

⑤FM 方法：FM 方法[21]也是一种情境感知的推荐方法，而且在预测精度和推荐时间方面要优于其他方法，例如 MV 方法等。FM 方法同时包含用户信任关系和情境信息，因而

① http: //www.trustlet.org/wiki/Extended_Epinions_dataset.

可以同时考虑情境和用户信任来做推荐。

(3) 推荐质量

①评价工具简介

本文采用MAE和RMSE方法来评估用户项目评级预测的准确性，采用Precision at k和NDCG at k方法来评估所推荐的k个项目的质量。

MAE和RMSE方法中，MAE值或RMSE值越小，就意味着预测精度越高，从而推荐质量越好。本文在平均绝对误差(MAE)和均方根误差(RMSE)的基础上依照本文度量的对象进行调整，将它们定义为：

$$RMSE = \sqrt{\frac{\sum_{ij}(RT_{ij} - \hat{RT}_{ij})^2}{N}} \tag{9}$$

$$RMSE = \sqrt{\frac{\sum_{ij}(RT_{ij} - \hat{RT}_{ij})^2}{N}} \tag{10}$$

RT_{ij}和$\hat{RT}_{ij}$分别指代用户i对项目j实际给出的评级和预测评级，N指代参与测试的样本总数。

对测试集中的每个用户u，Precision at k表示那部分处于预测评分最高的前k项、且出现在用户u的实验Top k列表中的项目。本文将用户u的评分项目按实际评分逆序排列，并选择前k个项目组成用户u的实验Top k列表。

推荐质量对评级最高的前k个推荐项目的位置敏感。运用标准化贴现累计收益(NDCG)计量方法来测度前k个推荐项目的质量。NDCG被定义为：

$$NDCG = Z_k \cdot \sum_{j=1}^{k} \frac{2^{RT(j)} - 1}{\log_2(1+j)} \tag{11}$$

RT(j)指代有序项目列表中第j位的项目评级，常数Z_k需满足理想状态下NDCG值为1。

②参数m_t和n_t的影响

在本文的方法中，参数m_t和n_t起着平衡角色数量和角色抽象程度的作用。如果m_t和n_t的值很大，那么挖掘出来的角色数就会减少，从而有很大部分用户不参与演绎任何或极少的角色，在这种情况下基于共同的情境感知行为以找到某用户的相似用户而不是基于角色集利用WSSQ算法进行相似度的计算和相似用户的选取，从而有损于推荐质量；而另一方面，如果m_t和n_t值过小，角色规模相应变小，在计算用户相似度时就会遇到“几乎不相似”的局面，影响到系统最终的判定。为了找到合适的、能够提升推荐质量的m_t和n_t值，设置实验比较不同的m_t和n_t值的情形下MAE、RMSE的变化情况。

图6展示了实验数据集上参数m_t和n_t对MAE及RMSE的影响，可以看出，m_t和n_t分别为750、2时MAE取到最小值0.605、RMSE取到最小值0.805，因此m_t和n_t的最优值应当分别为750、2。在接下来的比较与评价中，m_t和n_t也将取其最优值，以期推荐算法可以获得最好的推荐质量。

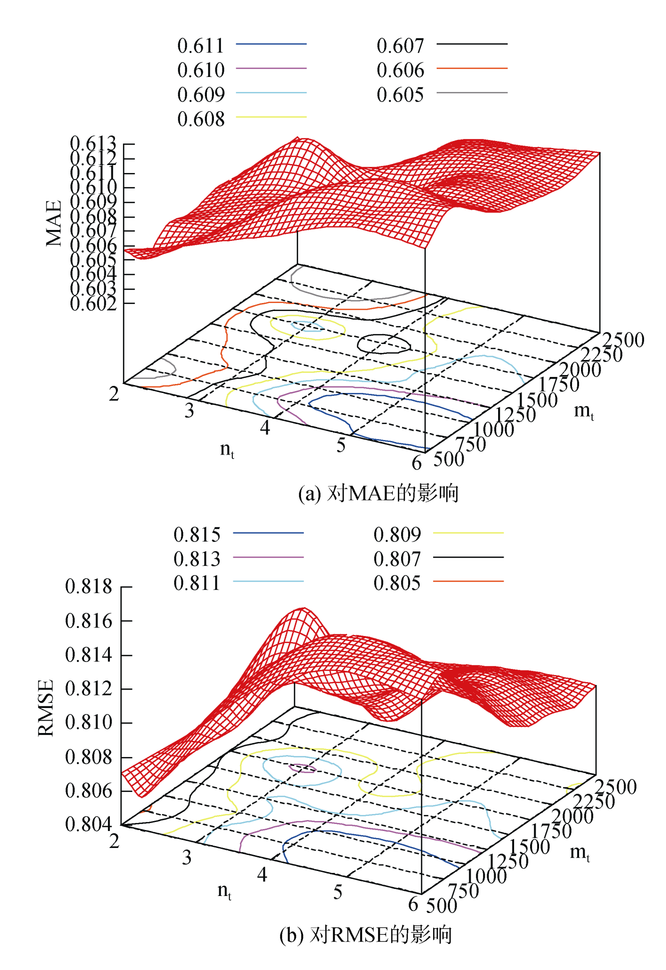


图6 实验集上参数m_t和n_t对MAE及RMSE的影响

(4) 基于角色的信任网络推荐(RRTN)质量评价

运用从20%到99%不等比例的训练数据来比较最终预测的准确度，准确度由MAE、RMSE方式衡量，例如90%比例下的结果则意味着运用随机选取90%的训练数据来预测剩下的10%的评分数据。而评分预测质量则由不同k值下的Precision at k值和NDCG at k值来衡量。

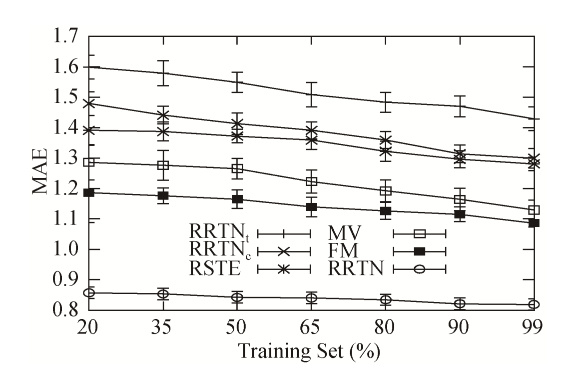


图7 不同推荐方法的MAE值表现

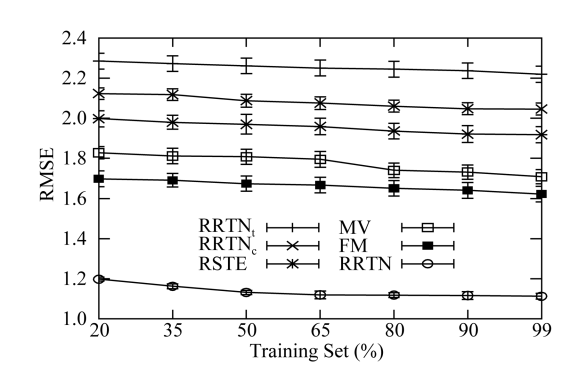


图 8　不同推荐方法的 RMSE 值表现

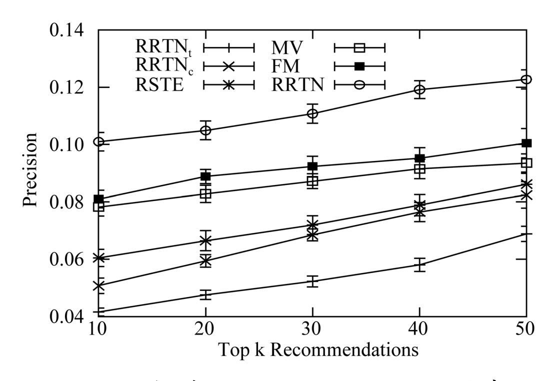


图 9　不同推荐方法的 Precision at k 值表现

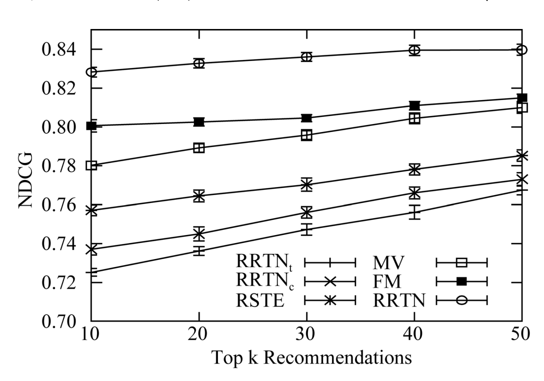


图 10　不同推荐方法的 NDCG at k 值表现

从图 7 至图 8 可以看出，RRTN 方法与其他方法相比有更高的预测精度，图 9 至图 10 则体现出 RRTN 方法在推荐质量上优于其他方法。

以 FM 方法为例。图 7、图 8 中，运用 20%的数据集时，RRTN 方法比 FM 方法在 MAE 值上要低 34%，在 RMSE 值上要低 48%；运用 99%的数据集时，RRTN 方法比 FM 方法在 MAE 值上要低 28%，在 RMSE 值上要低 51%。图 7、图 8 中所有方法的 MAE、RMSE 值都呈递减趋势，则印证了更多的训练数据可以得到更好的推荐结果。图 9 显示，当 k 值取 10 时，RRTN 方法至少优于其他方法 2%，当 k 值取 50 时，RRTN 方法至少优于其他方法 3%。图 10 显示，当 k 值取 10 时，RRTN 方法至少优于其他方法 2.8%，当 k 值取 50 时，RRTN 方法至少优于其他方法 2.9%。

从图 7 至图 10 可以看出，RRTN 能够做到比 RSTE 更精准的推荐，这主要有两方面的原因：RSTE 不是情境感知的推荐方式，它忽视了情境因素；RRTN 是基于一个密集的基于角色的信任网络来进行推荐的，很多隐性信任关系能够通过信任模型量化，而 RSTE 推荐只是基于稀疏的显性信任关系。此外，也表明了与 $RRTN_t$ 和 $RRTN_c$ 相比，RRTN 的推荐质量明显优于前两者。$RRTN_t$ 是情境独立的 RRTN 方法，它在计算用户 u 和 u'的相似度时只是基于他们的共同行为选择，而没有考虑情境 c 这一因素。$RRTN_c$ 方法没有为用户构建基于角色的信任网络，只是基于用户 u 在情境 c 下所演绎的角色来做推荐。RRTN 的推荐质量优于 $RRTN_t$，主要是因为前者考虑到情境因素；$RRTN_c$ 则忽略了用户之间的信任关系在现实中对用户的选择所造成的影响，用户往往倾向于选择其信任对象评价很高的项目。以上结果也正说明了信任关系和情境信息需要结合起来运用于推荐。

而 FM 方法虽然考虑进了信任关系和情境信息，但其表现依然不如 RRTN 方法，主要是因为 RRTN 方法引入了角色来表示用户群体的相同的情境感知行为。角色可以帮助系统决定用户的情境感知的兴趣偏好和信任关系。FM 方法则忽略了用户之间隐性的信任表达。

5　结　语

本文基于移动环境下移动数字图书馆为其用户提供个性化推荐服务的现实情况，以用户在不同情境中演绎不同角色、且相同角色用户对某些推送项目具有相同偏好作为理论基础，提出一种针对移动数字图书馆用户的情境感知的个性化推荐方式。首先利用角色挖掘算法在 UCB 矩阵中进行角色挖掘；然后构建基于角色的信任模型来测度任意两个用户间的信任值；之后，采用一种有效的 WSSQ 算法为用户 u 建立基于角色的信任网络，并保证 u 的信任对象和信任值都随情境和角色的变化而变化。这样的推荐方法通过角色集相似度来寻找信任用户，可以较好地解决用户间显性

信任数据的稀疏问题，实验结果也表明本文提出的推荐方法相对于其他方法具有更好的推荐质量。但在本文中，情境是事先定义好的，角色挖掘是在线下实现的，如果用户样本足够大，那么新的情境和角色会变得稀疏。因此，未来研究将设计一种有效且可扩展的角色挖掘算法使其可以适应新的情境和用户。

国家移动数字图书馆系统旨在建立一个网点遍布全国的知识王国，一个遍布全国的跨地区、跨部门、跨行业的科技、文化信息资源网络[22]，而在当下这种各大商业信息服务平台依托互联网环境发展个性化推荐已经成为趋势的情形下，单纯的资源内容推送难以突出图书馆本身的特点，也不能发挥馆藏的最大价值以及实现社会信息沟通的责任。移动数字图书馆的服务宗旨承自图书馆"每本书有其读者"的用户理念，在新形势下更应当借助于迅速发展的科技理论将深入而专业的读者服务精神进一步拓展，资源推荐系统的未来研究也应融入其中，笔者认为以下几点可以作为深入发展的参考:

(1) 建立用户个人账户，搜集更多的用户信息，并在已有的项目标签下进行细分，使推荐内容更加贴合用户的实际需要。用户的资源需求有时暗含在其学历、社会职务等个人信息中，如果仅考虑用户兴趣而忽视其作为社会人的角色特征，则可能会有失偏颇，如经济学又可分为经济生活常识、经济学学术论文，从而有区别地服务于非经济专业民众、商界人士、学界人士。

(2) 结合用户社会身份和工作需求，综合推荐服务、虚拟参考咨询服务、定题信息服务，进行专业咨询推送和专项跟进，使传统图书馆在服务专业人士上的优势项目得到进一步传承和加强。在讨论实体馆发展时，常将研究型图书馆与公共馆区分开来，前者的重点服务项目即为参考咨询，而当情况转变到移动数字图书馆上时，研究学者、专业人员的咨询需求依然存在。移动数字图书馆依托于互联网平台，可以结合利用的资源更多，服务的用户从行业、职业层级、空间分布等方面来看都更多样化，将推荐系统结合到咨询平台、课题服务平台上是经济社会发展对移动数字图书馆的要求。

参考文献:

[1] 王知津, 侯延香. 我国数字图书馆可持续发展的服务模式[J]. 大学图书馆学报, 2005, 23(5): 2-6. (Wang Zhijin, Hou Yanxiang. On the Service Pattern of the Sustainable Digital Library in China [J]. Journal of Academic Libraries, 2005, 23(5): 2-6.)

[2] 盛小平. 数字图书馆馆藏评价[J]. 图书情报工作, 2003, 47(5): 40-43. (Sheng Xiaoping. Collection Evaluation of Digital Libraries [J]. Library and Information Service, 2003, 47(5): 40-43.)

[3] Forestier M, Stavrianou A, Velcin J, et al. Roles in Social Networks: Methodologies and Research Issues [J]. Web Intelligence & Agent Systems, 2012, 10(1): 117-133.

[4] Adomavicius G, Tuzhilin A. Context-Aware Recommender Systems [C]. In: Proceedings of ACM Conference on Recommender Systems. ACM, 2008: 2175-2178.

[5] Anand S S, Mobasher B. Contextual Recommendation [A]. // From Web to Social Web: Discovering and Deploying User and Content Profiles [M]. Springer Berlin Heidelberg, 2006: 142-160.

[6] Bao T, Cao H, Chen E, et al. An Unsupervised Approach to Modeling Personalized Contexts of Mobile Users [J]. Knowledge & Information Systems, 2010, 31(2): 345-370.

[7] Sen S, Adomavicius G, Sankaranarayanan R, et al. Incorporating Contextual Information in Recommender Systems Using a Multidimensional Approach [J]. ACM Transactions on Information Systems, 2005, 23(1): 103-145.

[8] Karatzoglou A, Amatriain X, Baltrunas L, et al. Multiverse Recommendation: N-dimensional Tensor Factorization for Context-aware Collaborative Filtering [C]. In: Proceedings of ACM Conference on Recommender Systems (RecSys2010), Barcelona, Spain. 2010: 79-86.

[9] Rendle S, Gantner Z, Freudenthaler C, et al. Fast Context-aware Recommendations with Factorization Machines [C]. In: Proceedings of the International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR 2011), Beijing, China. 2011: 635-644.

[10] Massa P, Avesani P. Trust-aware Recommender Systems [C]. In: Proceedings of Conference on Recommender Systems. 2007: 17-24.

[11] Jamali M, Ester M. TrustWalker: A Random Walk Model for Combining Trust-based and Item-based Recommendation [C]. In: Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2009: 397-406.

[12] Jamali M, Ester M. Using a Trust Network to Improve Top-N Recommendation [C]. In: Proceedings of ACM Conference on Recommender Systems. ACM, 2009: 181-188.

[13] Dubois T, Golbeck J, Kleint J, et al. Improving Recommendation Accuracy by Clustering Social Networks with Trust [C]. In: Proceedings of ACM RecSys09 Workshop on Recommender Systems & the Social Web. 2009.

[14] Ma H, King I, Lyu M R. Learning to Recommend with Social Trust Ensemble [C]. In: Proceedings of the 32nd International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2009: 203-210.

[15] Golbeck J. Trust and Nuanced Profile Similarity in Online Social Networks [J]. ACM Transactions on the Web, 2009, 3(4): 3451-3459.

[16] McPherson M, Smithlovin L, Cook J M. Birds of a Feather: Homophily in Social Networks [J]. Annual Review of Sociology, 2001, 15(4): 344-349.

[17] Vaidya J, Atluri V, Guo Q. The Role Mining Problem: Finding a Minimal Descriptive Set of Roles [C]. In: Proceedings of the 12th ACM Symposium on Access Control Models and Technologies. 2007: 175-184.

[18] Tong H, Faloutsos C, Pan J Y. Fast Random Walk with Restart and Its Applications [C]. In: Proceedings of the 6th International Conference on Data Mining. IEEE Computer Society, 2006: 613-622.

[19] Hadjieleftheriou M, Srivastava D. Weighted Set-Based String Similarity [J]. Bulletin of the Technical Committee on Data Engineering, 2010, 33(1): 25-36.

[20] Liu H, Lim E P, Lauw H W, et al. Predicting Trusts Among Users of Online Communities: An EpinionsCase Study [C]. In: Proceedingsof the 9th ACM Conference on Electronic Commerce (EC-2008), Chicago, IL, USA. 2008: 310-319.

[21] Rendle S. Factorization Machines with libFM [J]. ACM Transactions on Intelligent Systems & Technology, 2012, 3(3): 219-224.

[22] 孟连生. 关于发展我国数字图书馆事业的几点思考[J]. 图书情报知识, 2002(1): 9-12. (Meng Liansheng. Some Thinking about How to Develop Digital Libraries in China [J]. Documentation, Information& Knowledge, 2002(1): 9-12.)

作者贡献声明:

洪亮: 提出研究思路, 设计研究方案, 实验的完成及分析;
钱晨: 方案的实现, 论文起草;
洪亮, 钱晨, 樊星: 论文最终版本修订。

利益冲突声明:

所有作者声明不存在利益冲突关系。

收稿日期: 2016-04-22
收修改稿日期: 2016-05-20

Context-aware Recommendation System for Mobile Digital Libraries

Hong Liang Qian Chen Fan Xing
(School of Information Management, Wuhan University, Wuhan 430072, China)

Abstract: [**Objective**] This paper proposes a context-aware recommendation system for the mobile digital libraries, with the help of the latter's collection features and users behaviors. [**Methods**] Based on the theory of similar users having similar choices, we first modeled the users' interests by introducing the concept of roles. Second, we designed an effective Weighted Set Similarity Query (WSSQ) algorithm to build a role-based trust network for the users. Finally, we modified the existing context-aware recommendation system, which was then evaluated with an Extended Epinions dataset. [**Results**] The proposed new recommendation system was feasible, and had better performance than other methods. [**Limitations**] The contexts and roles were not rich enough to process large user samples. [**Conclusions**] This study could help us improve the mobile digital library's resource recommendation system.

Keywords: Mobile digital library Context-aware recommendation WSSQ algorithm